

Penerapan Convolutional Neural Network (CNN) pada Klasifikasi Tanaman Apel Menggunakan Resnet-50

M. Fauzan Djafaar^{1*}, Mohamad Jamil²

^{1,2} Program Studi Teknik Informatika, Fakultas Teknik Universitas Khairun, Ternate, Indonesia

^{1*} canoxdjafaar@gmail.com, ² jamil@unkhair.ac.id,

^{*)} canoxdjafaar@gmail.com

Abstrak-Klasifikasi tanaman apel berbasis citra daun masih menghadapi tantangan berupa variasi bentuk, tekstur, pencahayaan, serta kemiripan visual dengan tanaman lain yang berpotensi menurunkan akurasi identifikasi. Permasalahan tersebut berdampak pada proses monitoring pertanian dan pengambilan keputusan yang memerlukan ketepatan tinggi. Penelitian ini memiliki tujuan untuk mengimplementasikan model Convolutional Neural Network (CNN), yaitu model pembelajaran mendalam yang dirancang untuk mengekstraksi fitur visual secara otomatis, pada klasifikasi tanaman apel dengan memanfaatkan arsitektur Residual Network lima puluh lapis (ResNet-50). ResNet-50 menggunakan mekanisme residual guna mengurangi penurunan performa pada jaringan dengan kedalaman lapisan yang tinggi. Hasil penelitian menunjukkan bahwa model CNN dengan arsitektur Resnet-50 mampu melakukan klasifikasi citra daun apel sehat dan busuk dengan akurasi terbaik sebesar 82,40% pada scenario pembagian dataset 80:20. Evaluasi ini menggunakan confusion matrix dan classification report menghasilkan nilai precision sebesar 0,86 pada kelas busuk dan 0,79 pada kelas sehat, serta nilai recall masing-masing sebesar 0,77 dan 0,88. temuan ini menunjukkan bahwasanya Resnet-50 memiliki kemampuan yang cukup baik dalam mengenali karakteristik visual daun apel dan dapat digunakan sebagai solusi klasifikasi tanaman berbasis citra digital.

Kata Kunci: Klasifikasi Citra, Tanaman Apel, Convolutional Neural Network, Residual Network Lima Puluh Lapis, Pembelajaran Mendalam

Abstract-Apple plant classification based on leaf images still faces challenges in the form of variations in shape, texture, lighting, and visual similarity with other plants, which can potentially reduce identification accuracy. This problem impacts agricultural monitoring and decision-making processes that require high accuracy. This research aims to apply the Convolutional Neural Network (CNN) method, a deep learning approach designed for automatically extracting visual features, to apple plant classification using a fifty-layer Residual Network (ResNet-50) architecture. ResNet-50 uses a residual mechanism to overcome performance degradation in very deep networks. The results showed that the CNN model based on the ResNet-50 architecture was able to classify healthy and rotten apple leaf images with the highest accuracy of 82.40% using the 80:20 dataset split scenario. Evaluation using a confusion matrix and classification report produced a precision value of 0.86 for the rotten class and 0.79 for the healthy class, while the recall values were 0.77 and 0.88, respectively. These findings indicate that ResNet-50 has a good capability in recognizing visual characteristics of apple leaves and can be effectively utilized as an image-based plant classification solution.

Keywords: Image Classification, Apple Plant, Convolutional Neural Network, Fifty-Layer Residual Network, Deep Learning

1. PENDAHULUAN

Kemajuan teknologi deep learning telah memberikan pengaruh signifikan di berbagai bidang, terutama dalam sistem otomatisasi berbasis citra digital untuk mendukung aktivitas manusia. Di sektor pertanian, identifikasi dan klasifikasi tanaman merupakan aspek penting yang menentukan keberhasilan pemantauan kondisi tanaman serta upaya pengendalian penyakit secara dini [1]. Informasi yang akurat mengenai jenis tanaman dan kondisi kesehatannya dapat membantu petani dalam menentukan strategi pemeliharaan yang tepat sehingga produktivitas pertanian dapat meningkat. Selain itu, identifikasi yang cepat juga berperan dalam mencegah penyebaran penyakit tanaman yang berpotensi menyebabkan kerugian ekonomi. Seiring meningkatnya kebutuhan pangan dan luas are budidaya pertanian, proses identifikasi tanaman secara otomatis menjadi kebutuhan yang semakin penting. Oleh karena itu, penerapan teknologi berbasis kecerdasan buatan menjadi salah satu pendekatan yang banyak dikembangkan dalam bidang pertanian modern [2].

Metode identifikasi tradisional yang mengandalkan observasi manusia sering kali menghadapi keterbatasan berupa subjektivitas, waktu yang lama, dan ketergantungan pada pengalaman ahli, sehingga kurang efisien ketika diterapkan pada skala besar. Perbedaan tingkat pengetahuan dan pengalaman antar pengamat dapat menyebabkan hasil identifikasi yang tidak konsisten. Selain itu proses pemeriksaan manual membutuhkan tenaga dan waktu yang cukup besar, terutama Ketika jumlah tanaman yang diamati sangat banyak [2].



Untuk mengatasi tantangan tersebut, pendekatan pembelajaran mesin berbasis Convolutional Neural Network (CNN) menjadi pilihan yang menjanjikan karena kemampuannya mengekstrak fitur visual kompleks secara otomatis dari citra tanpa memerlukan fitur manual yang rumit. CNN mampu mempelajari berbagai karakteristik visual seperti tekstur, warna, bentuk, dan pola spasial secara langsung dari data citra yang diberikan. Kemampuan tersebut bisa memungkinkan model menghasilkan representasi fitur yang lebih kaya dibandingkan metode ekstraksi fitur konvensional [3].

CNN merupakan bagian dari deep learning yang dikembangkan secara khusus untuk pemrosesan data visual, yang telah banyak digunakan dalam tugas klasifikasi citra tanaman maupun deteksi penyakit daun. Arsitektur CNN modern mampu mengidentifikasi pola tekstur, bentuk, dan fitur spasial pada citra tanaman dengan performa yang lebih unggul dibandingkan metode klasik, terutama pada dataset besar dan beragam [4].

Dalam konteks klasifikasi tanaman apel, tantangan utama yang sering muncul adalah variasi morfologi daun akibat faktor genetik dan lingkungan, serta noise berupa pencahayaan dan latar belakang yang tidak konsisten, yang dapat memengaruhi akurasi model. Untuk mengatasi hal ini, teknik transfer learning dengan memanfaatkan model CNN pra-latih telah menjadi strategi efektif untuk meningkatkan kemampuan generalisasi model, termasuk penggunaan arsitektur seperti Residual Network lima puluh lapis (ResNet-50) [5].

Pendekatan transfer learning memungkinkan model memanfaatkan pengetahuan yang telah diperoleh dari dataset besar sehingga proses pelatihan menjadi lebih efisien. Teknik ini juga dapat mengurangi kebutuhan data pelatihan yang sangat besar pada kasus-kasus tertentu. Berbagai klasifikasi tanaman dibandingkan pelatihan model dari awal (training from scratch). Dengan demikian, metode ini menjadi salah satu pendekatan yang banyak digunakan dalam penelitian klasifikasi citra berbasis CNN [5].

ResNet-50 adalah arsitektur CNN deep learning yang memperkenalkan residual learning untuk mengurangi masalah degradasi performa pada jaringan dengan kedalaman lapisan yang tinggi. Mekanisme tersebut memungkinkan gradien mengalir lebih baik dan efektif selama pelatihan, sehingga model mampu belajar representasi fitur yang lebih mendalam dan kompleks tanpa mengalami penurunan kinerja yang signifikan [6]. Keunggulan ini membuat ResNet-50 menjadi salah satu arsitektur yang paling populer dalam berbagai penelitian klasifikasi citra. Dengan jumlah lapisan yang cukup dalam, model mampu mengekstraksi informasi visual yang lebih detail dibandingkan arsitektur yang lebih sederhana.

Pendekatan ini telah banyak diterapkan di berbagai studi klasifikasi citra tanaman maupun penyakit daun dengan hasil yang baik. Sebagai contoh, penelitian penerapan ResNet-50 pada klasifikasi tanaman menggunakan citra daun menunjukkan bahwa model ini mampu membedakan klasifikasi dua kategori tanaman apel (sehat dan busuk) dengan akurasi kompetitif, serta memberikan solusi implementasi perangkat lunak berbasis desktop untuk identifikasi otomatis. Hasil tersebut menunjukkan bahwa ResNet-50 tidak hanya memiliki kemampuan klasifikasi yang tinggi, tetapi juga berpotensi untuk diimplementasikan pada aplikasi nyata. Kemampuan tersebut menjadi nilai tambah dalam pengembangan sistem pertanian cerdas yang membutuhkan proses identifikasi secara cepat dan otomatis [7].

Selain itu, penelitian perbandingan berbagai arsitektur CNN seperti ResNet-50, MobileNetV3, dan EfficientNet pada dataset penyakit daun tanaman menunjukkan bahwa ResNet-50 tetap menjadi salah satu arsitektur yang mencapai akurasi tinggi ketika diterapkan pada tugas klasifikasi yang kompleks, meskipun terdapat kompromi antara efisiensi komputasi dan kinerja model [8]. Studi lain yang fokus pada deteksi penyakit daun padi dengan arsitektur ResNet-50 memperlihatkan efektivitas model dalam mengenali banyak kelas penyakit secara otomatis [9]. Hasil penelitian tersebut menunjukkan bahwa ResNet-50 memiliki kemampuan yang baik dalam mengekstraksi fitur penting dari citra tanaman sehingga mampu menghasilkan prediksi yang akurat.

Penelitian-penelitian ini menegaskan bahwa penggunaan arsitektur CNN tingkat lanjut seperti ResNet-50 dapat menghasilkan suatu sistem klasifikasi tanaman secara lebih akurat dan efisien dibandingkan pendekatan manual atau metode pembelajaran yang lebih sederhana. Oleh karena itu, penelitian mengenai penerapan dari ResNet-50 pada klasifikasi tanaman apel masih relevan untuk dilakukan guna memperoleh model yang optimal dan dapat mendukung proses identifikasi tanaman secara otomatis [10].

Penelitian ini bertujuan untuk menerapkan arsitektur Convolutional Neural Network menggunakan model ResNet-50 dalam proses klasifikasi tanaman apel berdasarkan citra daun. Penelitian ini juga bertujuan untuk menganalisis kinerja model ResNet-50 dalam mengenali kategori daun tanaman apel, mengevaluasi tingkat akurasi yang dihasilkan, serta mengetahui efektivitas penggunaan Teknik transfer learning dalam meningkatkan performa klasifikasi. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan sistem identifikasi tanaman apel yang otomatis, akurat, dan efisien sehingga dapat mendukung penerapan teknologi kecerdasan buatan pada sektor pertanian modern.

2. METODE PENELITIAN

Metodologi penelitian ini dirancang untuk menjabarkan secara rinci tahapan dalam penelitian klasifikasi tanaman apel menggunakan Convolutional Neural Network (CNN)[10]. Studi ini akan memanfaatkan 5.000 gambar daun


apel sebagai dataset utama untuk melakukan proses klasifikasi. Tujuan utama dari metodologi ini adalah untuk menciptakan urutan kerja yang logis dan sistematis agar hasil penelitian dapat dicapai secara konsisten dan terukur sehingga memberikan gambaran yang jelas mengenai rancangan sistem klasifikasi visual yang dikembangkan.

Tahap pertama dalam studi ini berupa pengumpulan data citra daun apel. Sebanyak 3206 gambar dikumpulkan dari berbagai sumber, termasuk pengambilan langsung di lapangan maupun sumber dataset terbuka yang memiliki label kelas yang jelas. Setiap citra daun apel direkam dengan berbagai variasi kondisi pencahayaan, orientasi dan latar belakang untuk memperkaya variasi data, sesuai dengan praktik umum dalam penelitian klasifikasi tanaman berbasis citra digital [11]. Data yang representatif ini penting untuk memastikan model dapat mengenali pola visual secara general sehingga dapat diterapkan pada kondisi asli di lapangan.

Tahapan berikutnya adalah pembagian dataset. Dataset citra dibagi secara acak menjadi tiga bagian utama: data pelatihan (training set), data validasi (validation set), dan data pengujian (test set). Pembagian data yang baik merupakan langkah krusial dalam penelitian pembelajaran mesin karena menentukan kemampuan model dalam mempelajari pola pada data pelatihan dan mengukur performa pada data yang benar-benar belum pernah dilihat sebelumnya [12]. Rasio umum yang digunakan adalah 70% dari data untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian.


Pada fase pembangunan model, digunakan arsitektur ResNet-50, salah satu varian CNN yang telah terbukti efektif dalam menangani masalah klasifikasi citra berskala besar karena mekanisme residual learning-nya yang mampu memperbaiki aliran gradien pada jaringan sangat dalam tetapi terus direplikasi dalam penelitian kontemporer. Model ResNet-50 akan dimodifikasi sehingga lapisan terakhirnya sesuai dengan jumlah kelas target klasifikasi daun apel dalam penelitian ini. Pendekatan dilakukan melalui transfer learning yang diimplmentasikan melalui pemanfaatan bobot awal model yang telah dilatih pada dataset besar seperti ImageNet untuk mempercepat proses pembelajaran dan meningkatkan kemampuan generalisasi model [13].

Setelah model dilatih, dilakukan tahap evaluasi performa. Evaluasi dilakukan terhadap data pengujian menggunakan metrik seperti akurasi, presisi, recall, serta skor F1 untuk memberikan deskripsi lengkap terkait kinerja model untuk konteks pengenalan visual. Selain itu, matriks kebingungan (confusion matrix) disajikan untuk menganalisis distribusi kesalahan klasifikasi antara kelas-kelas yang diprediksi dibandingkan dengan label sebenarnya. Evaluasi metrik yang komprehensif ini penting untuk memvalidasi bahwa model bukan hanya bekerja baik secara keseluruhan, tetapi juga pada setiap kelas individu [14]. Gambar 1 adalah rute penelitian.



Gambar 1. Alur Pengolahan Data Citra

Dalam penelitian ini, alur pengolahan data citra dirancang melalui serangkaian tahapan sistematis guna memastikan model pembelajaran mesin dapat berjalan secara optimal. Tahapan pertama diawali dengan persiapan data, yang meliputi proses pengumpulan dataset citra serta penginputan dataset tersebut ke dalam sistem. Selanjutnya, dilakukan tahapan prapemrosesan (*preprocessing*), di mana data citra yang telah dimasukkan akan melalui proses penyesuaian ukuran (*resize*) agar memiliki dimensi yang seragam dan siap diolah oleh algoritma. Tahap akhir merupakan pemrosesan model, yang mencakup proses pelatihan (*training*) data untuk membangun model klasifikasi serta validasi data guna mengevaluasi tingkat akurasi dan performa model yang dihasilkan. Keseluruhan alur kerja ini memberikan gambaran yang komprehensif mengenai mekanisme pengolahan data citra dari awal hingga pengujian model, sebagaimana disajikan dalam bentuk gambar 2.



Gambar 2. Alur Pengembangan Sistem dan Pengolahan Data

Berikut ini adalah penjelasan dari gambar 2, yaitu:

1. Alur Pengembangan Sistem dan Pengolahan Data, terbagi menjadi dua bagian utama, yaitu Siklus Pengembangan Perangkat Lunak dan Tahapan Pengolahan Dataset Citra.
2. Pada bagian Siklus Pengembangan Perangkat Lunak, proses dimulai dengan tahap Analisis untuk menganalisis kebutuhan sistem yang akan dibangun.
3. Tahap berikutnya adalah Design, di mana dilakukan perancangan arsitektur, antarmuka (*UI/UX*), dan alur dari sistem perangkat lunak.
4. Setelah perancangan selesai, dilakukan proses Code yaitu mengimplementasikan rancangan ke dalam baris kode program (coding).
5. Siklus ini diakhiri dengan tahap Test untuk melakukan pengujian sistem guna memastikan seluruh fungsi berjalan dengan baik dan bebas dari bug.
6. Pada bagian Tahapan Pengolahan Dataset Citra, alur dimulai dengan Pengumpulan setiap Dataset yang akan digunakan dalam penelitian atau pengembangan model.
7. Langkah selanjutnya adalah Menginput sebuah Dataset ke dalam lingkungan sistem atau platform pemrosesan data.
8. Setelah data masuk, dilakukan proses *Resize* dari Data Citra untuk menyelaraskan dan menyesuaikan ukuran piksel gambar agar sesuai dengan spesifikasi input model.
9. Data yang telah disesuaikan kemudian masuk ke tahap *Training* setiap Data, yaitu proses melatih model kecerdasan buatan menggunakan data citra tersebut.
10. Tahap terakhir dari pengolahan citra adalah Validasi Setiap Data untuk menguji serta mengukur tingkat akurasi dan performa model yang telah dilatih.

2.1. Pengumpulan Data

Dataset yang dijadikan fondasi penelitian bersumber dari platform Kaggle, sebuah repositori data global yang menyediakan berbagai sampel citra untuk kebutuhan analisis saintifik. Data tersebut secara spesifik mencakup berbagai karakteristik visual dari daun apel yang merepresentasikan spektrum kondisi biologis luas, mulai dari jaringan yang sehat hingga dedaunan yang telah terinfeksi atau mengalami proses pembusukan. Pemilihan dataset ini didasarkan pada variabilitas fitur yang ditawarkan, yang sangat esensial untuk meningkatkan akurasi dan reliabilitas dalam pemodelan identifikasi penyakit tanaman secara otomatis [15].

Secara kuantitatif, penelitian ini melibatkan total 3206 entitas citra yang dikelompokkan secara dikotomis terdapat daun apel sehat serta busuk sebagai kategori fungsional utama [16]. Kelompok pertama merepresentasikan sampel daun apel dalam kondisi fisiologis yang optimal atau sehat. Sementara itu, kelompok kedua mencakup sampel daun yang menunjukkan tanda-tanda pembusukan atau degradasi biologis yang direpresentasikan dalam Gambar 3. Pembagian data yang terstruktur ini memungkinkan dilakukannya komparasi fitur morfologi yang mendalam untuk membedakan antara jaringan tanaman yang normal dan yang terdampak patogen.

Berikut ini adalah gambar daun buah apel sehat dan gambar daun buah apel busuk yaitu:



Gambar 3. Jenis Daun Apel Sehat dan Busuk

2.2. Data Preprocessing

Pemisahan dataset ke dalam dua kelompok utama, yakni data latih (training data) serta data uji (testing data), dilakukan untuk memastikan bahwa model yang dibangun mampu melakukan prediksi secara akurat terhadap data yang belum pernah digunakan selama proses pelatihan. Data latih digunakan oleh model untuk mempelajari pola, karakteristik, dan fitur penting yang terdapat pada citra daun apel, sedangkan data uji dimanfaatkan untuk mengukur kemampuan model dalam melakukan generalisasi terhadap data baru [17]. Melalui proses ini, peneliti dapat mengevaluasi apakah model yang dikembangkan benar-benar mampu mengenali pola yang relevan atau hanya menghafal data pelatihan. Dengan demikian, pembagian dataset menjadi data latih dan data uji merupakan langkah penting dalam proses evaluasi kinerja model, karena dapat memberikan penilaian yang lebih objektif mengenai tingkat akurasi prediksi yang dihasilkan terhadap data yang belum pernah digunakan sebelumnya.

Selain proses pembagian dataset, tahapan praproses data juga dilakukan untuk meningkatkan kinerja model klasifikasi. Salah satu langkah penting dalam tahap ini adalah melakukan penyesuaian ukuran citra pada seluruh dataset. Dataset yang dikumpulkan umumnya memiliki ukuran resolusi yang berbeda-beda, sehingga dapat menyulitkan model dalam mengenali pola yang seragam pada data. Perbedaan ukuran citra dapat menyebabkan ketidaksesuaian dimensi input pada jaringan saraf konvolusional serta mempengaruhi proses ekstraksi fitur. Oleh karena itu, seluruh citra daun apel pada dataset diubah ukurannya agar memiliki dimensi yang sama sehingga model dapat memproses data secara lebih stabil dan terstruktur selama proses pelatihan maupun pengujian.

Dalam penelitian ini, seluruh citra daun apel disesuaikan menjadi ukuran 224×224 piksel. Penyesuaian ukuran ini dilakukan agar dataset sesuai dengan dimensi input standar yang digunakan oleh arsitektur ResNet-50 yang telah dilatih sebelumnya. Dengan ukuran input yang seragam, model dapat mengekstraksi fitur visual secara lebih efektif dan menemukan pola-pola penting yang terdapat pada citra daun apel. Proses penyeragaman ukuran citra ini juga membantu meningkatkan efisiensi komputasi serta mempermudah proses pembelajaran model. Dengan demikian, penggunaan ukuran citra 224×224 piksel diharapkan mampu membantu model dalam mengidentifikasi pola pada dataset secara lebih konsisten dan menghasilkan prediksi klasifikasi yang lebih akurat.

2.3. Pengembangan Model

Penelitian ini memanfaatkan model ResNet-50, yang menjadi salah satu arsitektur dalam pendekatan Convolutional Neural Network (CNN) banyak digunakan dalam bidang pemrosesan citra digital dan pengenalan pola. Arsitektur ResNet-50 dikenal memiliki kemampuan yang sangat baik dalam mengekstraksi berbagai fitur penting dalam citra melalui struktur jaringan yang dalam, sehingga mampu meningkatkan performa klasifikasi pada berbagai jenis objek visual. Keunggulan utama dari ResNet-50 terletak pada penggunaan konsep Residual Learning yang memungkinkan jaringan untuk mengatasi permasalahan degradasi performa yang sering terjadi pada jaringan saraf yang sangat dalam. Dengan adanya mekanisme residual connection, model dapat mempertahankan aliran informasi selama proses pelatihan sehingga menghasilkan representasi fitur yang lebih efektif. Oleh karena itu, penggunaan ResNet-50 dalam penelitian ini diharapkan dapat memberikan hasil klasifikasi secara lebih akurat terhadap identifikasi citra daun apel, baik yang termasuk dalam kategori sehat maupun yang mengalami kerusakan.

Secara konseptual, penelitian ini menerapkan model ResNet-50 sebagai salah satu bentuk implementasi arsitektur CNN yang telah banyak dimanfaatkan dalam analisis citra berbasis pembelajaran mendalam. Model ini dirancang untuk mampu mempelajari representasi fitur secara mendalam melalui jaringan yang memiliki banyak lapisan, sehingga dapat meningkatkan kemampuan sistem dalam melakukan proses klasifikasi objek visual. Salah satu karakteristik utama dari ResNet-50 adalah penerapan konsep Residual Learning, yaitu mekanisme yang memungkinkan jaringan saraf mempertahankan aliran informasi antar lapisan sehingga dapat mengurangi permasalahan penurunan kinerja pada jaringan yang sangat dalam. Dengan pendekatan tersebut, model dapat mempelajari pola-pola penting dari citra secara lebih optimal, sehingga penerapannya dalam penelitian ini diharapkan mampu meningkatkan tingkat akurasi dalam proses pengenalan dan klasifikasi citra daun apel.

Berikut ini adalah codingan perintah untuk memerintakan Impor Library TensorFlow yaitu:

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam

import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.metrics import confusion_matrix, classification_report
```

Gambar 4. Codingan dari ResNet50

Kode pada gambar 4 menunjukkan proses inisialisasi berbagai pustaka yang digunakan dalam pengembangan model klasifikasi citra berbasis deep learning. Library utama yang digunakan adalah TensorFlow, khususnya modul Keras, yang berfungsi untuk membangun dan melatih model ResNet50 sebagai arsitektur utama penelitian. Selain itu, digunakan ImageDataGenerator untuk proses augmentasi dan preprocessing data citra, serta beberapa layer seperti Dense, GlobalAveragePooling2D, dan Dropout untuk membentuk struktur klasifikasi pada model. Optimasi model dilakukan menggunakan algoritma Adam, yang dikenal efisien dalam proses pembaruan bobot. Library tambahan seperti NumPy digunakan untuk komputasi numerik, Matplotlib dan Seaborn digunakan untuk visualisasi grafik, dan Scikit-learn untuk evaluasi model melalui confusion matrix dan classification report. Secara keseluruhan, kode ini merepresentasikan tahap persiapan lingkungan pemrograman yang komprehensif untuk mendukung proses pelatihan, evaluasi, dan analisis performa model secara sistematis dalam penelitian klasifikasi citra.

Lebih lanjut, integrasi berbagai pustaka tersebut mencerminkan pendekatan yang terstruktur dalam pengembangan sistem berbasis deep learning, di mana setiap library memiliki peran spesifik dalam mendukung alur kerja penelitian mulai dari pengolahan data, pembangunan model, hingga evaluasi hasil.

Penggunaan modul-modul dari TensorFlow Keras memungkinkan proses implementasi model menjadi lebih efisien dan modular, sementara dukungan pustaka visualisasi dan evaluasi memberikan kemudahan dalam menganalisis performa model secara kuantitatif dan visual.

Dengan demikian, konfigurasi kode ini tidak hanya berfungsi sebagai dasar implementasi teknis, tetapi juga sebagai fondasi metodologis yang penting dalam menghasilkan penelitian yang sistematis, terukur, dan dapat direproduksi.

2.4. ResNet-50

Pada tahapan berikutnya, proses perancangan arsitektur CNN dilakukan sebagai klasifikasi terhadap dataset citra daun apel yang digunakan dalam penelitian. Tahap ini merupakan bagian penting dalam pengembangan sistem karena arsitektur jaringan saraf menentukan bagaimana model mengekstraksi fitur visual dari citra dan menggunakannya untuk proses klasifikasi. Dalam implementasinya, penelitian ini memanfaatkan TensorFlow sebagai pustaka pembelajaran mesin yang memiliki kemampuan komputasi tinggi dan banyak digunakan dalam pengembangan model deep learning. Melalui pustaka tersebut, model yang terlatih sebelumnya (pre-trained model) bisa dengan mudah diakses dan digunakan kembali untuk proses klasifikasi citra. Secara khusus, penelitian ini memanggil arsitektur ResNet-50, yaitu salah satu model jaringan saraf konvolusional yang telah dilatih menggunakan dataset berskala besar dan dikenal memiliki kemampuan yang baik dalam melakukan ekstraksi fitur citra. Dengan memanfaatkan model ResNet-50 yang telah dilatih sebelumnya, proses pelatihan model dalam penelitian ini dapat dilakukan secara lebih efisien serta meningkatkan kemampuan sistem untuk mengenali pola visual terhadap citra daun apel.

Model ResNet-50 merupakan salah satu arsitektur dalam pendekatan CNN yang diperkenalkan oleh Microsoft Research pada tahun 2015 dengan tujuan meningkatkan kemampuan jaringan saraf dalam mempelajari representasi fitur dari data citra. Istilah ResNet sendiri adalah singkatan Residual Network, merujuk pada konsep penggunaan blok residu (residual block) di dalam arsitektur jaringan. Konsep ini memungkinkan jaringan untuk mempelajari fungsi residual sehingga dapat mempertahankan aliran informasi antar lapisan dan mengurangi permasalahan degradasi performa yang sering terjadi pada jaringan yang sangat dalam. ResNet-50 memiliki kedalaman jaringan sebanyak 50 lapisan dan termasuk dalam keluarga model ResNet yang juga memiliki varian lain dengan kedalaman lebih besar, misalnya ResNet-101 serta ResNet-152. Karena keunggulannya dalam mengekstraksi fitur visual yang kompleks, model ini banyak dimanfaatkan dalam berbagai penelitian di bidang pengolahan citra digital dan pembelajaran mendalam [18].

Secara umum, arsitektur ResNet-50 tersusun atas beberapa komponen utama yang bekerja secara berurutan dalam melakukan proses ekstraksi dan klasifikasi fitur citra. Proses dimulai dengan lapisan konvolusi awal yang berfungsi sebagai ekstraksi fitur dasar terhadap citra masukan, seperti garis tepi, tekstur, dan pola sederhana. Selanjutnya, citra diproses melalui serangkaian blok residu yang masing-masing terdiri dari beberapa lapisan konvolusi yang dilengkapi dengan shortcut connection. Mekanisme shortcut connection memungkinkan informasi dari lapisan terdahulu diteruskan secara langsung ke lapisan berikutnya tanpa harus melewati seluruh proses konvolusi, sehingga dapat mempertahankan stabilitas proses pembelajaran pada jaringan yang dalam. Setelah melewati blok residu terakhir, fitur yang dihasilkan akan diproses melalui lapisan global pooling untuk mengurangi dimensi spasial dari peta fitur sebelum akhirnya diteruskan ke lapisan fully connected yang menghasilkan keluaran berupa hasil klasifikasi [19].

Selain itu, penggunaan konsep residual dalam arsitektur ResNet-50 memberikan keuntungan yang signifikan dalam proses pelatihan jaringan saraf dalam. Pada jaringan konvensional yang memiliki banyak lapisan, sering terjadi permasalahan yang dikenal sebagai vanishing gradient, yaitu kondisi ketika nilai gradien menjadi sangat kecil sehingga proses pembelajaran menjadi tidak efektif. Dengan adanya mekanisme residual connection, gradien dapat mengalir lebih stabil selama proses backpropagation, sehingga model dapat dilatih dengan jumlah lapisan yang lebih banyak tanpa mengalami penurunan kinerja. Hal ini menjadikan ResNet-50 sebagai salah satu arsitektur yang efektif dalam menangani permasalahan klasifikasi citra dengan tingkat kompleksitas yang tinggi [20].

3. HASIL DAN PEMBAHASAN

Pada pembahasan ini disajikan hasil penerapan metode CNN dengan arsitektur ResNet-50 dalam melakukan klasifikasi citra daun apel melalui dua kategori, yaitu daun sehat serta daun busuk. Dataset yang digunakan telah melalui tahap preprocessing berupa normalisasi dan penyesuaian ukuran citra menjadi 224×224 piksel sesuai input model. Data kemudian dipisah menjadi data latih dan data uji secara proporsional guna menjaga keseimbangan antar kelas. Hasil pelatihan menunjukkan bahwa model mampu mempelajari fitur penting dari citra secara bertahap, yang ditunjukkan oleh peningkatan akurasi dan penurunan nilai loss selama proses training. Pada penggunaan epoch sebanyak 40, performa model mengalami peningkatan yang signifikan hingga mencapai kondisi stabil (konvergen), di mana penambahan epoch lebih lanjut tidak memberikan peningkatan yang berarti dan berpotensi menimbulkan overfitting [21].

3.1. Membuat Deskripsi Skenario

Berdasarkan skenario yang telah dibuat dengan total dataset sebanyak 3206 citra daun apel, penelitian ini menerapkan beberapa variasi pembagian data, 70:30, 80:20, serta 90:10, guna menganalisis pengaruh proporsi data latih dan data uji terhadap kinerja model berbasis CNN dengan arsitektur ResNet-50. Dataset yang diimplementasikan bersifat seimbang, di mana masing-masing kelas sehat dan busuk memiliki jumlah yang sama, sehingga dapat meminimalkan bias dalam proses pelatihan. Pada skenario 70:30, model dilatih menggunakan sebagian besar data namun tetap mempertahankan jumlah data uji yang cukup besar untuk evaluasi yang representatif. Sementara itu, pada skenario 80:20, proporsi data latih lebih besar memungkinkan model mempelajari pola citra lebih optimal, sehingga umumnya menghasilkan performa yang lebih baik. Adapun pada skenario 90:10, jumlah data latih yang sangat dominan memberikan kemampuan pembelajaran yang maksimal, namun jumlah data uji yang relatif sedikit dapat membatasi evaluasi performa model secara menyeluruh serta meningkatkan potensi terjadinya overfitting. Oleh karena itu, perbandingan ketiga skenario ini menjadi penting untuk menentukan konfigurasi pembagian dataset yang paling efektif dalam menghasilkan model dengan tingkat akurasi dan kemampuan generalisasi yang optimal [22].

Berikut ini adalah bentuk dalam tabelnya yang menyajikan pembagian dataset secara sistematis berdasarkan skenario 70:30, 80:20, dan 90:10, sehingga memudahkan dalam memahami distribusi data latih dan data uji terhadap masing-masing kelas, yaitu sehat dan busuk yaitu:


Tabel 1. Membuat Perbandingan Skenario

Skenario	Train Sehat	Train Busuk	Total Train	Test Sehat	Test Busuk	Total Test	Akurasi
70:30	1122	1122	2244	481	481	962	79.73%
80:20	1282	1282	2564	321	321	642	82.40%
90:10	1443	1443	2886	160	160	320	79.69%

Tabel 1 menunjukkan bahwa perbandingan performa model pada tiga skenario pemisahan dataset, seperti 70:30, 80:20, dan 90:10, dalam penelitian klasifikasi citra daun apel dengan metode CNN dengan arsitektur ResNet-50. Berdasarkan hasil yang diperoleh, skenario 80:20 menghasilkan akurasi tertinggi sebesar 82,40%, dibandingkan dengan skenario 70:30 yang mencapai 79,73% dan skenario 90:10 sebesar 79,69%. Hal ini menunjukkan bahwa proporsi data latih dan data uji yang seimbang untuk skenario 80:20 memberikan kemampuan pembelajaran yang optimal sekaligus evaluasi yang cukup representatif. Sementara itu, pada skenario 70:30, meskipun data uji lebih banyak sehingga evaluasi lebih kuat, jumlah data latih yang lebih sedikit membatasi kemampuan model dalam mempelajari pola secara maksimal. Di sisi lain, skenario 90:10 memiliki jumlah data latih yang paling besar, namun performa akurasi tidak meningkat secara signifikan karena keterbatasan data uji dalam merepresentasikan kemampuan generalisasi model serta potensi terjadinya overfitting. Oleh karena itu, hasil ini mengindikasikan bahwa skenario 80:20 merupakan konfigurasi yang paling efektif dalam menghasilkan performa model yang optimal dan stabil.

3.2. Menghitung Model Akurasi

Perhitungan akurasi model dilakukan untuk mengukur tingkat ketepatan prediksi yang dihasilkan oleh model CNN melalui arsitektur ResNet-50 dalam mengklasifikasikan data. Secara sistematis, akurasi dihitung sebagai perbandingan terhadap jumlah prediksi yang benar (gabungan true positive dan true negative) dengan total keseluruhan data yang diuji. Nilai ini memberikan gambaran umum mengenai sejauh mana model mampu mengenali pola pada data uji yang belum pernah digunakan sebelumnya. Dalam proses evaluasi, akurasi biasanya dihitung setelah model memproses prediksi untuk seluruh data uji, sehingga hasilnya mencerminkan kemampuan generalisasi model. Meskipun demikian, akurasi perlu dianalisis bersama metrik lain seperti precision, recall, serta f1-score guna memastikan bahwa model tidak hanya memiliki tingkat ketepatan yang tinggi secara keseluruhan, tetapi juga mampu memberikan performa yang seimbang pada setiap kelas yang diklasifikasikan [23]. Berikut ini adalah gambar dari model akurasinya




Gambar 5. Model Akurasi

Gambar 5 menunjukkan grafik akurasi model selama proses pelatihan hingga 40 epoch, dengan perbandingan antara akurasi data latih dan data validasi pada model berbasis Convolutional Neural Network menggunakan arsitektur ResNet-50. Terlihat bahwa akurasi data latih mengalami peningkatan secara bertahap dari nilai awal yang relatif rendah hingga mencapai kisaran sekitar 0,75, yang menandakan bahwa model mampu mempelajari pola terhadap data pelatihan yang progresif. Sementara itu, akurasi data validasi menunjukkan fluktuasi yang cukup signifikan pada beberapa epoch awal, namun secara umum juga mengalami tren peningkatan hingga mendekati atau bahkan melampaui akurasi data latih pada epoch tertentu. Fluktuasi tersebut dapat disebabkan oleh variasi data validasi atau sensitivitas model terhadap karakteristik data yang diuji. Secara keseluruhan, kedekatan nilai antara kurva akurasi training dan validation menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik serta tidak mengalami overfitting yang signifikan, walaupun masih terdapat variasi performa yang perlu diperhatikan untuk optimasi lebih lanjut.

3.3. Menghitung Model Loss

Perhitungan nilai loss pada model dilakukan untuk mengukur tingkat kesalahan antara hasil prediksi yang dihasilkan oleh model CNN terhadap arsitektur ResNet-50 dan label sebenarnya pada data. Dalam konteks

klasifikasi biner, fungsi loss yang umum digunakan adalah binary cross-entropy, yang menghitung selisih antara probabilitas prediksi dan nilai target dalam bentuk distribusi probabilitas [24]. Secara matematis, loss dihitung dengan mengakumulasi kesalahan pada setiap sampel dalam satu batch, kemudian dirata-ratakan untuk memperoleh nilai loss keseluruhan. Nilai ini selanjutnya digunakan dalam proses backpropagation untuk memperbarui bobot jaringan melalui algoritma optimasi seperti Adam optimizer. Dengan demikian, proses perhitungan loss berperan penting dalam mengarahkan model untuk terus memperbaiki parameter internalnya agar mampu menghasilkan prediksi yang semakin akurat dan mendekati nilai sebenarnya.




Gambar 6. Hasil Dari Confusion Matrix

Gambar 6 menunjukkan bahwa nilai loss pada model berbasis CNN melalui arsitektur ResNet-50 mengalami penurunan secara konsisten selama proses pelatihan hingga 40 epoch. Baik loss pada data latih maupun data validasi menunjukkan tren menurun, yang menunjukkan bahwa model semakin mampu mengurangi kesalahan prediksi seiring bertambahnya epoch. Selain itu, kedekatan antara kedua kurva menunjukkan bahwa model tidak mengalami overfitting yang signifikan serta memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah digunakan sebelumnya.

3.4. Hasil Confusion Matrix dan Hasil Klasifikasi

Hasil evaluasi menggunakan Confusion Matrix memberikan gambaran rinci mengenai kinerja model dalam mengklasifikasikan citra daun apel ke dalam kategori sehat dan busuk. Matriks ini menggambarkan jumlah prediksi yang benar seperti true positive dan true negative, serta kesalahan prediksi seperti false positive dan false negative, sehingga memungkinkan analisis yang lebih mendalam dibandingkan hanya menggunakan akurasi [25]. Berdasarkan hasil klasifikasi yang diperoleh, sebagian besar data berhasil dilakukan prediksi dengan benar, yang menggambarkan bahwa model memiliki kemampuan yang baik dalam mengenali pola visual pada citra. Namun, terdapat sejumlah kecil kesalahan klasifikasi yang umumnya terjadi pada citra dengan karakteristik yang mirip atau kualitas gambar yang kurang optimal. Oleh karena itu, analisis confusion matrix tidak hanya menunjukkan tingkat keberhasilan model, tetapi juga membantu mengidentifikasi kelemahan model yang dapat diperbaiki melalui peningkatan kualitas data atau optimasi model lebih lanjut.

Meskipun demikian, masih terdapat sejumlah kecil kesalahan klasifikasi yang terjadi pada beberapa data uji. Kesalahan ini umumnya disebabkan oleh kemiripan karakteristik visual antara daun sehat dan daun yang mengalami kerusakan ringan, serta faktor eksternal seperti pencahayaan yang tidak merata atau kualitas citra yang kurang optimal. Oleh sebab itu, analisis hasil klasifikasi tidak hanya berfokus pada tingkat keberhasilan model, tetapi juga pada identifikasi kelemahan yang dapat diperbaiki. Upaya peningkatan performa dapat dilakukan melalui penambahan dataset, penerapan teknik augmentasi data, serta optimasi parameter model agar hasil klasifikasi menjadi lebih akurat dan konsisten.



Gambar 7. Hasil Confusion Matrix

Gambar 7 menampilkan confusion matrix yang menampilkan evaluasi kinerja model berbasis CNN terhadap arsitektur ResNet-50 dalam mengklasifikasikan citra daun apel ke dalam dua kelas, yaitu busuk dan sehat. Berdasarkan matriks tersebut, model berhasil mengklasifikasikan data busuk dengan benar sebanyak 247 (true negative) dan data sehat dengan benar sebanyak 282 (true positive). Namun, masih ditemukan kesalahan klasifikasi, yaitu sebanyak 74 data busuk yang diprediksi sebagai sehat (false positive) dan 39 data sehat yang diprediksi sebagai busuk (false negative). Hasil tersebut menunjukkan bawasannya model memiliki performa cukup baik untuk mengenali kedua kelas, terutama pada kelas sehat yang memiliki jumlah prediksi benar lebih tinggi, meskipun masih terdapat beberapa kesalahan yang dapat disebabkan oleh kemiripan visual antara daun sehat dan busuk atau variasi kualitas citra yang digunakan dalam dataset.

Tabel 2. Classification Report

Kelas	Precision	Recal	F-1Score	Support
Busuk	0.86	0.77	0.81	321
Sehat	0.79	0.88	0.83	321
Accuracy	-	-	0.82	642
Macro Avg	0.83	0.82	0.82	642
Weighted Avg	0.83	0.82	0.82	642

Tabel 2 menyajikan hasil evaluasi model klasifikasi berbasis CNN melalui arsitektur ResNet-50 menggunakan metrik precision, recall, f1-score, serta support untuk masing-masing kelas. Pada kelas busuk, model memperoleh nilai precision sebesar 0,86, yang menunjukkan bahwa sebagian besar prediksi busuk sudah tepat, namun recall sebesar 0,77 mengindikasikan masih terdapat beberapa data busuk yang tidak terdeteksi dengan baik. Sementara itu, pada kelas sehat, nilai recall yang lebih tinggi yaitu 0,88 mengartikan kemampuan model secara baik untuk mengenali data sehat, meskipun precision-nya sedikit lebih rendah yaitu 0,79. Nilai f1-score yang relatif seimbang pada kedua kelas (0,81 untuk busuk dan 0,83 untuk sehat) menunjukkan bahwa model memiliki kinerja yang cukup konsisten guna mengklasifikasikan kedua kategori. Secara keseluruhan, model memiliki akurasi 0,82 serta nilai macro average dan weighted average yang hampir sama, yang menandakan bahwa performa model cukup stabil dan tidak mengalami bias signifikan terhadap salah satu kelas.

4. KESIMPULAN

Berdasarkan analisis terhadap hasil dan pengamatan, bisa disimpulkan bahwa penerapan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 mampu memberikan kinerja yang cukup baik dalam klasifikasi citra daun apel ke dalam kategori sehat dan busuk. Dengan menggunakan dataset sebanyak 3206 citra, model menghasilkan akurasi sebesar 82% yang didukung oleh nilai precision, recall, dan f1-score yang relatif seimbang pada masing-masing kelas. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang

cukup stabil, meskipun masih terdapat kesalahan klasifikasi yang kemungkinan disebabkan oleh kemiripan karakteristik visual antar kelas serta variasi kualitas citra. Selain itu, performa model juga dipengaruhi oleh pembagian dataset, jumlah epoch, dan proses preprocessing yang diterapkan. Secara keseluruhan, penelitian ini membuktikan bahwa ResNet-50 menjadi pendekatan yang efektif sebagai klasifikasi citra tanaman, tetapi masih memerlukan optimasi lebih lanjut seperti peningkatan kualitas dan jumlah data, serta penyesuaian parameter pelatihan untuk mencapai tingkat akurasi yang lebih tinggi dan lebih optimal dalam implementasi nyata.

REFERENSI

- [1] Z. Cao and S. Sun, "A Review of Computer Vision and Deep Learning Applications in Crop Growth Management," 2025, doi: 10.3390/app15158438.
- [2] P. K. Illa, S. Ravuri, R. Vuppala, and B. M. Reddy, "Deep Learning Methods for Plant Disease Identification using Leaf Images : A Survey," *2023 Int. Conf. Sustain. Comput. Smart Syst.*, no. Iccss, pp. 307–316, 2023, doi: 10.1109/ICSCSS57650.2023.10169260.
- [3] Y. Liu, H. Pu, and D. Sun, "Trends in Food Science & Technology Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices," *Trends Food Sci. Technol.*, vol. 113, no. April, pp. 193–204, 2021, doi: 10.1016/j.tifs.2021.04.042.
- [4] M. Nikesh, D. Rohini, S. Shaankari, M. Bharathi, and T. A. S. Srinivas, "Verdant Vision : CNNs Revolutionizing Plant Leaf Disease Identification," no. 2, pp. 1–6, 2024, doi: 10.48001/JoCSVL.2024.121-6.
- [5] C. A. Technology and I. Technologies, "Apple Disease Recognition Based on Comprehensive Application of Residual Neural Network," vol. 0, 2023, doi: 10.3233/FAIA230765.
- [6] L. M. K. Sheikh, A. Shaikh, A. Sandupatla, R. Pudale, A. Bakare, and P. M. Chavan, "Classification of Simple CNN Model and ResNet50," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, no. 4, pp. 4606–4610, 2024, doi: 10.22214/ijraset.2024.60677.
- [7] S. A. Wicaqsana, A. Luthfiarta, A. Putri, D. Mareta, and M. S. Fitri, "Evaluation of the Accuracy and Efficiency of Deep CNN Architecture in Feature Extraction for Guava Disease Classification," vol. 9, no. 6, pp. 3798–3809, 2025, doi: 10.30871/jaic.v9i6.11655.
- [8] T. D. Salka, M. Hanafi, S. M. Syed, and A. Abdul, "State-of-the-Art CNN Models for Plant Disease Classification : A Comparative Study," vol. 33, no. 6, pp. 2541–2563, 2025, doi: 10.47836/pjst.33.6.07.
- [9] I. S. In and I. S. In, "Plant Disease Detection using ResNet," 2023, doi: 10.1109/ICICT57646.2023.10133938.
- [10] M. R. Bhat *et al.*, "Apple diseases : detection and classification using transfer learning," vol. 15, pp. 27–37, 2023, doi: 10.15586/qas.v15iSP1.1167.
- [11] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using Deep Learning for Image-Based Plant Disease Detection," *Front. Plant Sci.*, vol. 7, no. September, pp. 1–10, 2016, doi: 10.3389/fpls.2016.01419.
- [12] D. Learning, "Plant Disease Detection and Classification by Deep Learning," *Nature*, vol. 29, no. 7553, pp. 1–73, 2019, doi: 10.3390.
- [13] B. Prashanthi, A. V. Praveen Krishna, and C. Mallikarjuna Rao, "A Comparative Study of Fine-Tuning Deep Learning Models for Leaf Disease Identification and Classification," *Eng. Technol. Appl. Sci. Res.*, vol. 15, no. 1, pp. 19661–19669, 2025, doi: 10.48084/etasr.9017.
- [14] J. G. A. Barbedo, "Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification," *Comput. Electron. Agric.*, vol. 153, pp. 46–53, 2018, doi: 10.1016/j.compag.2018.08.013.
- [15] R. Javed, A. M. Malik, A. F. Mirza, S. Aslam, A. Shabbir, and H. Tauseef, "Early Detection and Classification of Apple Leaf Diseases Using Deep Learning Technique," vol. 4, no. 3, pp. 86–100, 2024, doi: 10.62019.
- [16] M. R. Mulia, A. B. Kaswar, D. D. Andayani, A. Sadri, U. N. Makassar, and P. Korespondensi, "KLASIFIKASI KANDUNGAN NUTRISI BUAH PISANG BERDASARKAN FITUR TEKSTUR DAN WARNA LAB MENGGUNAKAN JARINGAN SYARAF TIRUAN BERBASIS PENGOLAHANCITRA DIGITAL," vol. 11, no. 3, pp. 507–518, 2024, doi: 10.25126/jtiik.938332.
- [17] P. Studi *et al.*, "Klasifikasi Jenis Daun Tumbuhan Herbal Berdasarkan Lontar Usada Taru Pramana Menggunakan CNN Classification of Herbal Plant Leaf Types Based on Lontar Usada Taru Pramana Using," vol. 23, no. 1, pp. 271–283, 2024, doi: 10.62411/tc.v23i1.9510.
- [18] W. S. Amurrokhman, "PERBANDINGAN RESNET50, MOBILENETV2, DAN MOBILENETV3-LARGE DALAM KLASIFIKASI MOTIF BATIK INDONESIA BERBASIS TRANSFER LEARNING," vol. 11, no. 1, pp. 1457–1467, 2026, doi: 10.36341/rabit.v11i1.4579.
- [19] T. Pascal Munthe and M. Akbar, "Klasifikasi Citra Biji Kopi Temanggung Menggunakan Residual Network



- (ResNet-50),” *J. Pustaka Data (Pusat Akses Kaji. Database, Anal. Teknol. dan Arsit. Komputer)*, vol. 5, no. 1, pp. 94–102, 2025, doi: 10.55382/jurnalpustakadata.v5i1.1028.
- [20] L. M. K. Sheikh, A. Shaikh, A. Sandupatla, R. Pudale, A. Bakare, and P. M. Chavan, “Classification of Simple CNN Model and ResNet50,” no. April, 2024, doi: 10.22214/IJRASET.2024.60677.
- [21] Y. A. Abdillah and K. Kusriani, “Corn Leaf Disease Classification Optimization Using Resnet50 Architecture Utilizing Bayesian Optimization,” *J. Electr. Eng. Comput.*, vol. 7, no. 1, pp. 8–15, 2025, doi: 10.33650/jeeecom.v7i1.9809.
- [22] Arimbi Puspitasari, Diana Sava Salsabila, and Dwi Roliawati, “Penerapan ResNet50-CNN untuk Optimalisasi Klasifikasi pada Data Fashion,” *Indones. J. Data Sci.*, vol. 3, no. 1, pp. 1–12, 2025, doi: 10.30989/ijds.v3i1.1533.
- [23] E. Ariawan, “Perbandingan Performa Arsitektur Convolutional Neural Network Menggunakan Transfer Learning untuk Model Deteksi Kesehatan Daun,” *J. Bus. Audit Inf. Syst.*, vol. 8, no. 1, pp. 1–12, 2025, doi: 10.30813/jbase.v8i1.8116.
- [24] S. Khorla and R. Singh, “Predicting Lung Cancer Using ResNet-50 Deep Residual Learning Model using Relu-Memristor Activation Function,” vol. 29, no. 3, doi: 10.4186/ej.2025.29.3.45.
- [25] P. A. Azli, A. Syahrani, and G. Y. Swara, “Segmentasi Citra Daun Tomat untuk Klasifikasi Penyakit Tanaman Menggunakan Support Vector Machine (SVM),” vol. 10, no. 4, pp. 997–1008, 2025, doi: 10.30591/jpit.v10i4.9404.